

Preliminary communication

Production of a Porosity Map by Kriging in Sandstone Reservoirs, Case Study from the Sava Depression

Tomislav MALVIĆ

INA-Industrija nafte, d.d., Exploration and Production of Oil and Gas, Reservoir Engineering and Field Development Dept., Zagreb, Croatia
Faculty of mining, Geology and Petroleum Engineering, Institute of Geology and Geological Engineering, Zagreb, Croatia

e-mail: tomislav.malvic@ina.hr

12

Abstract: Variogram analyses and usages of geostatistical interpolations have been standard analytical tools in Croatian geology in the last five years. Such analyses have especially been applied in the mapping of petroleum geological data. In this paper, spatial modelling of porosity data and, consequently, kriging mapping are described for a relatively large dataset obtained at an oil field located in the Croatian part of Pannonian basin (Sava depression). Analyzed datasets included porosity values measured in a sandstone reservoir of Pannonian age. The original dataset can be considered as a rare extensive porosity set available for Croatian hydrocarbon reservoirs. It made possible very reliable semivariogram modelling and kriging interpolation of porosity. The obtained results point out kriging as the most appropriate interpolation approach for porosity, but also for other geological data in sandstone reservoirs of Miocene age.

Keywords: porosity, semivariogram, kriging, oil reservoir, Sava depression, Croatia

1. Introduction

Statistics play an important role in geological modelling, providing possibilities of applying probability, hypothesis testing, different estimation, simulation techniques, etc. There are plenty of excellent books dedicated to use of statistics and geostatistics in geology and geosciences in general, like those by Journel and Huijbregts (1978), Isaaks and Srivastava (1989), Deutsch and Journel (1992), Jensen et al. (2000) and others.

There are several reasons to observe porosity as the most important reservoir parameter. Pore space defines fluid volume inside a rock and, consequently, reserves and very often represent an independent regression variable for saturation or permeability estimation. Sometimes different porosity correction techniques are applied. For example, to find a true porosity distribution in sediments that include hydrated minerals such as smectite, porosity data have to be corrected to account for the H_2O residing in smectite interlayers (Brown and Ransom, 1996). Moreover, porosity is often calculated using different logs of geophysical measurements in wells (like in this analysis). These measurements almost always need to be corrected in some way. For example, Thomas and Smith (1970) described how vugular porosity can be a correction term in estimation of oil yields and oil-shale reserves from density logs. Also, the effects of the combination of pressure and oil-base mud can lead to very large corrections of 5-10 porosity units calculated from compensated neutron log (Peeters et al., 1999). Generally, clastic sediments may have a strong deterministic component to their permeability variation what can be observed in the experimental semivariogram (Jensen et al., 1996). Of course, similar regularity in porosity data collected in clastic sediments of Miocene age in the Croatian part of the Pannonian basin can also be recognized from the shapes of experimental semivariograms (Malvić, 2003a,b).

Geostatistics represents the best interpolation approach for mapping different geological variables like porosity, permeability, depth and thickness, especially in sandstones. Many other rocks, like breccia, tectonized carbonates, magmatic and metamorphic rocks, include a significantly larger amount of stochastic components in porosity distribution. As a result, semivariogram models include many more uncertainties.

Prethodno priopćenje

Izrada karte poroznosti krigiranjem u pješčenjačkim ležištima, primjer iz Savske depresije

Tomislav MALVIĆ

INA-Industrija nafte, d.d., SD Istraživanje i proizvodnja nafte i plina,
Sektor za razradu, Zagreb
Rudarsko-geološko-naftni fakultet, Zavod za geologiju i geološko
inženjerstvo, Zagreb

e-pošta: tomislav.malvic@ina.hr

13

Sažetak: Variogramске анализе те употреба геостатистичке интерполације представљају у задњих пет година стандардни алат у хрватској геологији. Такве анализе посебно су примјенљиване приликом кртирања нафтно-геолошких података. У овоме чланку описани су просторно моделирање података порозности те кртирање с помоћу кртирања начинено за релативно велики улазни скуп вредности прикупљеним на нафтном пољу смештеном у хрватском дијелу Панонскога базена, тј. у подручју Савске депресије. Анализирани скуп података обухватио је вредности порозности у пješčenjačком лежишту панонске старости. Изворни подаци, својом бројношћу, рјетко су обиман скуп вредности порозности доступних у лежиштима угљиководика у Хрватској. То је омогућило врло поуздано семивариограмско моделирање те интерполацију тих података кртирањем. Кrigeова метода (кртирање) истакнута је као најпримјеренија интерполацијска техника за порозност, али и друге геолошке податке у пješčenjačким лежиштима миоцenske старости.

Кljučне riječi: порозност, семивариограм, кртирање, лежиште нафте, Савска депресија, Хрватска

1. Uvod

Statistika ima važnu ulogu kod geološkog modeliranja. Njezini alati omogućavaju računanje vjerojatnosti, testiranje hipoteza, upotrebu različitih procjena, simulacija i drugoga. Također postoji obilje vrlo kvalitetnih knjiga posvećenih upotrebi statistike i geostatistike u geologiji te općenito geoznanostima, poput onih kojima su autori Journel i Huijbregts (1978), Isaaks i Srivastava (1989), Deutsch i Journel (1992), Jensen i dr. (2000), i drugi.

Nekoliko je razloga zašto se poroznost promatra kao najvažniji ležišni parametar. Porni prostor određuje količinu fluida u stijeni, a time i rezerve, te je vrlo često nezavisna regresijska varijabla pri računanju zasićenja ili propusnosti. Pri računanju poroznosti primjenjuju različite korekcijske tehnike. Na primjer, računanje točne poroznosti u sedimentima koji sadrže hidratne minerale poput smektita, uključuje korekciju za količinu H_2O koja preostaje u međuslojevima između smektita (Brown i Ransom, 1996). Nadalje, poroznost je često izračunana iz različitih dijagrama geofizičkih mjerenja u bušotinama (poput vrijednosti dobivenih interpolacijom i opisani u ovome radu). Često takva mjerenja treba prilagoditi za neki faktor. Na primjer, Thomas i Smith (1970) su opisali kako sekundarna poroznost može biti korigirajući faktor pri računanju rezervi te općenito nafte nakupljene u matičnim stijenama poput šejlova. Nadalje, efekt kombinacije pritiska i isplake na bazi nafte može zahtijevati vrlo velike korekcije (od 5 do 10 dijelova jedinica) poroznosti izračunane kompenziranom neutronsom karotažom (Peeters i dr., 1999). Općenito, klastični sedimenti mogu iskazati snažnu determinističku komponentu ako se promatraju varijacije propusnosti, a što opet može biti zabilježeno na odgovarajućim eksperimentalnim semivariogramima (Jensen i dr., 1996). Naravno, slična pravilnost može se opaziti na podacima poroznosti, npr. u klastičnim miocenskim starosti u hrvatskom dijelu Panonskoga bazena (Malvić, 2003a,b).

Geostatistika je najbolji interpolacijski pristup za krtiranje različitih geoloških varijabli poput poroznosti, propusnosti, dubine i debljine, posebno u pješčenjacima. Mnoge druge stijene, poput breča, tektoniziranih karbonata, magmatskih i metamorfnih stijena, sadrže znatno veći iznos stohastičke komponente u razdiobi poroznosti

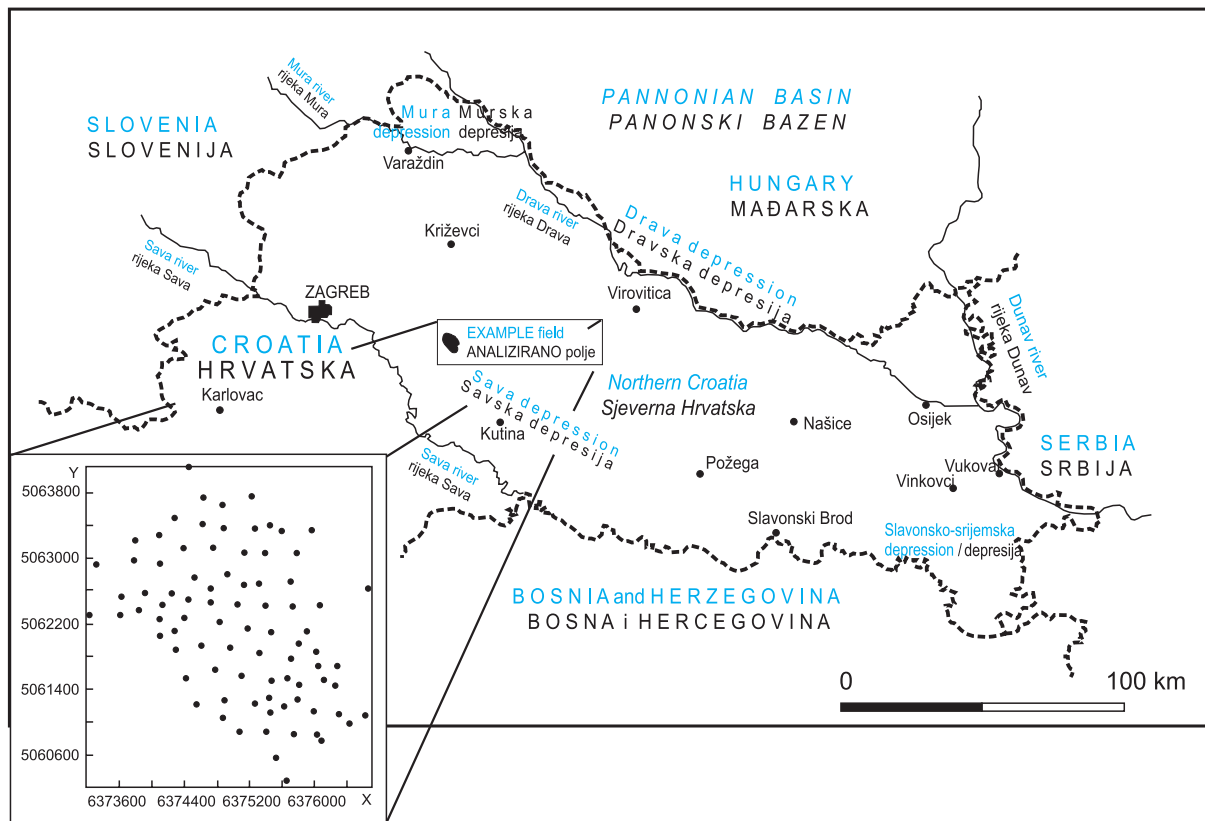


Fig. 1. Location map and distribution of porosity samples

Slika 1. Položajna karta s rasporedom uzoraka poroznosti

Porosity values used in this study are derived from geophysical measurements in wells or laboratory analyses of cores, averaged and spatially estimated through semivariograms and kriging maps. Sandstones are recognized as a rock-type where degree of homogeneity is not strongly characterized by stochastic behaviour. It means that porosity distribution can often clearly indicate on sedimentation environment conditions.

Porosity variations in the observed reservoir are explained by spatial analyses. The first, simplified semivariograms in selected reservoir were published by Her-nitz et al. (2001). The analysis was performed for vertical porosity values, including a calculation of variance and a specific correction. In this paper, semivariogram analysis by program Variowin 2.2. (Pannatier, 1996) is made in the horizontal plane, including a significant larger number of values.

2. Example Porosity Dataset

The applicability of the proposed kriging interpolation method is tested by means of porosity dataset of 82 values (Fig. 1) obtained at example field located in the western part of the Sava depression.

Original porosity values are calculated (from logs of geophysical measurements in wells) for a sandstone oil reservoir interval. This reservoir is of the Pannonian age

(Late Miocene). Analyzed sandstones dominantly consist of mica and quartz grains, with minor content of clay minerals. The compaction did not have any influence on porosity values in the analyzed sandstone. Based on this criterion, this sandstone differs from a similar sandstone described in the Bjelovar subdepression (located about 100 km to the northeast) where, due to significant differences in depths of the same reservoir, compaction significantly reduced porosity (Malvić et al., 2005).

Distribution of original porosity values selected in classes is shown in Fig. 2. It could be approximated by (some kind of) normal distribution curve. The characteristic statistical values of input dataset are shown in Table 1.

Table 1. Statistics of input porosity values

| Statistics parameters | Input dataset |
|-----------------------|---------------|
| Average porosity | 15.13% |
| Variance | 16.41 |
| Minimum | 0.00% |
| Maximum | 21.91% |




Fig. 2. Histogram of input porosity values

Slika 2. Histogram ulaznih vrijednosti poroznosti

15

te semivariogramsko modeliranje sadrži znatno više nesigurnosti.

Vrijednosti poroznosti upotrijebljene u ovoj interpretaciji izvedene su iz geofizičkih mjerenja u bušotini ili iz laboratorijskih analiza jezgara, osrednjene te prostorno procijenjene upotrebom semivariograma i krigiranja. Pješčenjaci su promatrani kao litotip relativno velike homogenosti, odnosno stijene u kojima petrofizikalni parametri nisu obilježeni značajnom stohastičkom komponentom. To također podrazumijeva da poroznost može vrlo često jasno ukazati na taložne uvjete i okoliše.

Varijacije poroznosti u analiziranom ležištu objašnjene su prostornom analizom. Prva, pojednostavnjena semivariogramska analiza na odabranom ležištu objavljena je u radu Hernitza i dr. (2001). U tom članku analiza je načinjena na ulaznom skupu vertikalnih vrijednosti poroznosti uz dodatno računanje varijance te načinjenu specifičnu korekciju. U ovome radu semivariogramska analiza programom Variowin 2.2. (Pannatier, 1996) načinjena je u vodoravnoj ravnini uz znatno veći broj vrijednosti.

2. Testni ulazni skup vrijednosti poroznosti

Upotrebljivost predložene interpolacijske metode krigiranja testirana je na ulaznom skupu od 82 vrijednosti poroznosti (slika 1). Podaci su prikupljeni na oglednom polju, smještenom u zapadnom dijelu Savske depresije.

Izvorne vrijednosti poroznosti izračunane su (s dijagrama geofizičkih mjerenja u bušotinama) za interval pješčenjačkog ležišta panonske staroste (gornji miocen). Analizirani pješčenjaci dominantno su sastavljeni od minerala tinjaca i kvarca, s malim udjelom minerala glina. Utjecaj kompakcije na poroznost nije zabilježen, za razliku od analize sličnih sedimenata načinjene u Bjelovarskoj uleknini (smještene oko 100 km sjeveroistočno) gdje se, zahvaljujući značajnim razlikama u dubinama istoga ležišta na malome prostoru, opazio utjecaj kompakcije na značajno smanjenje poroznosti u pojedinim dijelovima (Malvić i dr., 2005).

Raspodjela vrijednosti poroznosti svrstanih u razrede prikazana je na slici 2. Ona može (no samo približno) biti aproksimirana krivuljom normalne razdiobe. Karakteristične statističke vrijednosti ulaznog skupa podataka prikazane su u tablici 1.

Tablica 1. Statistika ulaznih vrijednosti poroznosti

| Statističke vrijednosti | Ulazni skup podataka |
|-------------------------|----------------------|
| Prosječna poroznost | 15,13 % |
| Varijanca | 16,41 |
| Minimum | 0,00 % |
| Maksimum | 21,91 % |




Fig. 3. Semivariogram surface map

Slika 3. Karta semivariogramске površine

16

3. Semivariogram Analysis and Kriging Maps

The semivariogram surface map (Fig. 3), calculated for original porosity values, indicates two existing semivariogram axes that correspond to field structural trends. The primary semivariogram axis has the NW-SE trend (135° - 315°) and the secondary one is characterized by the NE-SW trend (45° - 225°).

The parameters for experimental semivariogram were tested several times and finally the primary semivariogram axis (Fig. 4) was calculated using 15 lags, lag length of 400 meters, direction of 135° and angle tolerance of

45° . The same procedure was done for the secondary semivariogram axis in the direction of 225° (Fig. 5). Semivariogram parameters for both axes are shown in Table 2. The kriging map is shown in Fig. 6.

4. Conclusions

There is no doubt that kriging interpolation, including 82 available point-data, is the best mapping approach for porosity interpolation in the selected sandstone reservoir. In such a case, exact interpolators (methods appreciating hard-data values as constant) are a much better selection for interpolation than methods of simple matrix-smoothing (like moving average) or simple assignment




Fig. 4. Experimental semivariogram and spherical theoretical model of input dataset (primary axis)

Slika 4. Eksperimentalni semivariogram i sferni teorijski model za ulazni skup mjerenja (primarna os)

Table 2. Semivariogram parameters for the input values
 Tablica 2. Semivariogramski parametri ulaznog skupa vrijednosti

| | Primary semivariogram axis (135°) Primarna semivariogramska os (135°) | Secondary semivariogram axis (225°) Sekundarna semivariogramska os (225°) |
|--------------------------------------|---|--|
| | 15 lags, lag length 400 m, angle tolerance 45° 15 razreda, širina pojedinačnog razreda 400 m, kutna tolerancija 45 | |
| Nugget / Odstupanje | 4,76 | 7,63 |
| Sill / Prag | 11,56 | 9,11 |
| Range / Doseg | 2318 | 1312 |
| Theoretical model Teorijski model | Spherical / Sferni | Spherical / Sferni |

3. Semivariogramska analiza i karte dobivene krigiranjem

Karta semivariogramske površine (slika 3) izrađena je na temelju ulaznog skupa vrijednosti poroznosti. Na njoj se jasno uočavaju dvije postojeće semivariogramske osi koje ujedno odgovaraju strukturnim osima polja. Primarna semivariogramska os ima trend pružanja SZ-JI (135°-315°), a sekundarna SI-JZ (45°-225°).

Parametri eksperimentalnog semivariograma provjereni su nekoliko puta te ja na kraju primarna semivariogramska os (slika 4) izračunana na temelju 15 razreda, uz širinu od 400 metara, pravac pružanja od 135° te kutnu toleranciju od 45°. Jednaki postupak načinjen je

na sekundarnoj semivariogramskoj osi, no na pravcu pružanja od 225° (slika 5). Semivariogramski parametri za obje osi prikazani su u tablici 2, dok je karta izrađena s pomoću interpolacije krigiranjem prikazana na slici 6.

4. Zaključci

Nema sumnje kako je interpolacija krigiranjem, načinjena na 82 ulazne vrijednosti, najbolji mogući pristup pri kartiranju poroznosti u analiziranom pješčenjačkom ležištu. U takvim slučajevima, točni interpolatori poput krigiranja (odnosno metode koje poštuju ulazne vrijednosti kao nepromjenjive) uvijek će dati znatno bolja rješenja nego li ih je moguće postići s metodama poput




Fig. 5. Experimental semivariogram and spherical theoretical model of input dataset (secondary axis)
 Slika 5. Eksperimentalni semivariogram i sferni teorijski model za ulazni skup mjerenja (sekundarna os)

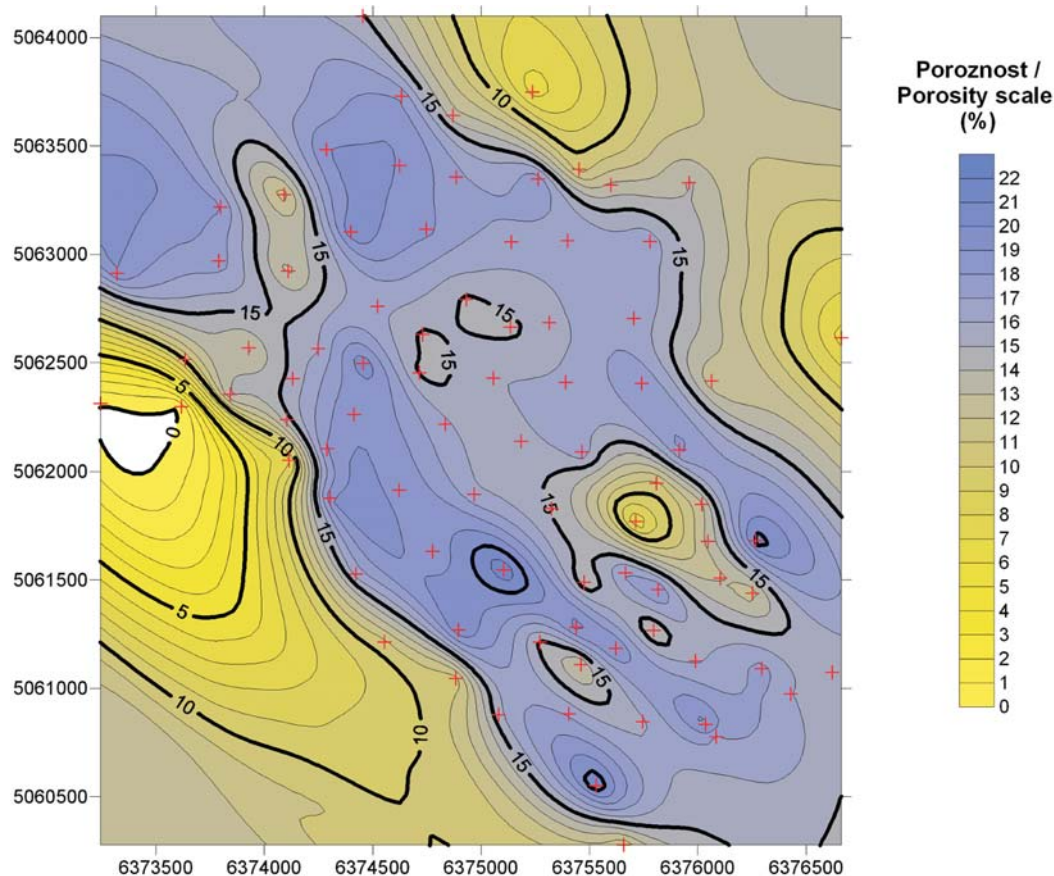


Fig. 6. The kriging porosity map of input values

Slika 6: Karta vrijednosti poroznosti dobivena interpolacijom krigiranjem

of point value to zones (like nearest neighbourhood). In this particular case the following results are obtained:

- The analysis was successfully applied in a homogeneous sandstone of Pannonian age (Late Miocene).
- The kriging porosity map very clearly indicates several porosity maximums, mostly located along the direction NW-SE, which corresponds to the structural maximum.
- It could be interesting to interpret depositional history of such maximums. The sandstone depositions, especially of coarse-grained material, were active in the deepest part of the basin. Strong uplifting, along marginal field faults in Late Miocene and Pliocene, inverted such structure in anticline, with higher porosities in central parts.
- The ratio of semivariogram ranges mostly follow the ratio between geological structural axes. The range of primary axis is 2318 meters and of secondary axis 1312 meters (ratio 1.77:1.00).
- Due to a huge nugget effect, but also small number of data pairs in the first class, the interpretation of the secondary semivariogram needs to be done carefully. Generally, porosity values change much faster across

secondary axis than along the main structural axis. The nugget effect of 50% will practically cut the range value at secondary axis in half.

- The obtained kriging map represents the best porosity interpolation, one can make for the analyzed reservoir.

Acknowledgements

I wish to thank the author of program VARIOWIN 2.2., Mr. Yvan Pannatier, for being able to use one of the most popular freeware software for semivariogram analysis. Variowin copyright © 1993, 1994, 1995 Yvan Pannatier - all Rights Reserved. The map is obtained by interpolation using the licensed version of the Surfer 8.0 program.

Furthermore, presented results are a part of a multi-disciplinary geostatistical research performed in 2007 within the projects entitled *Stratigraphical and geomathematical researches of petroleum geological systems in Croatia* (project no. 195-1951293-0237, leader Prof. Dr. Josipa Velić), financed by the Ministry of Science, Education and Sport of the Republic of Croatia.

pokretne sredine ili najbližeg susjedstva (koja i nije metoda procjene, već dodjeljivanja postojećih vrijednosti zoni). U prikazanoj analizi postignuti su sljedeći rezultati:

- ❑ Analiza je uspješno primijenjena u homogenom pješčenjačkom ležištu panonske starosti (gornji miocen).
- ❑ Karta nastala primjenom krigranja vrlo jasno prikazuje nekoliko maksimuma poroznosti koji su najvećim dijelom smješteni na pravcu pružanja SZ-JI, što odgovara strukturnom maksimumu, tj. vršnom dijelu strukture.
- ❑ Stoga je zanimljivo uvesti u interpretaciju i taložnu povijest takvih maksimuma. U skladu s prihvaćenom taložnom slikom, sedimentacija pješčenjaka, posebno krupnozrnastog materijala, odvijala se u najdubljim dijelovima bazena. Naknadno je u gornjem miocenu i pliocenu došlo do snažnog izdizanja uzduž rubnih rasjeda polja, što je rezultiralo u inverziji taložnog prostora (stvaranje antiklinale) u kojem su najveće vrijednosti poroznosti ostale vezane uz središnji dio strukture.
- ❑ Dosezi semivariograma uglavnom se međusobno odnose poput veličina geoloških strukturnih osi. Doseg primarne osi je 2318 metara, a sekundarne 1312 metra (odnos je 1,77:1,00).
- ❑ Zahvaljujući velikom odstupanju semivariograma, te malom broju parova podataka izračunanom u prvom semivariogramskom razredu, veličine na sekundarnoj

osi treba pažljivo interpretirati. Općenito, vrijednosti poroznosti znatno se brže mijenjaju uzduž sekundarne osi, nego li uzduž glavne strukturne osi. Zabilježeno odstupanje od gotovo 50 % praktično smanjuje za polovicu vrijednost dosega na sekundarnoj osi.

- ❑ Karta izrađena s pomoću krigranja najbolji je prikaz interpolacije vrijednosti poroznosti koju je moguće izraditi za analizirano ležište.

Zahvala

Zahvaljujem autoru programa VARIOWIN 2.2., gosp. Yvanu Pannatieru, za slobodnu upotrebu jednog od najpopularnijih programa za semivariogramsku analizu. Sva prava na Variowin © 1993, 1994, 1995 pridržava Yvan Pannatier. Karta je izrađena licenciranom inačicom programa Surfer 8.0.

Prikazani rezultati dio su multidisciplinarnog geostatičkog istraživanja načinjenog tijekom 2007. godine na projektu *Stratigrafska i geomatematička istraživanja naftnogeoloških sustava u Hrvatskoj* (projekt broj 195-1951293-0237, voditelj prof. dr. sc. Josipa Velić), financiranog od strane Ministarstva znanosti, obrazovanja i športa Republike Hrvatske.

19

References / Literatura

- Brown, K. M., Ransom, B. (1996): Porosity corrections for smectite-rich sediments; impact on studies of compaction, fluid generation, and tectonic history. *Geology*, 24, 9, p. 843-846.
- Deutsch, C. V., Journel, A. G. (1992): *GSLIB Geostatistical Software Library and User's Guide*, Oxford University Press, New York.
- Hernitz, Z., Bokor, N., Malvić, T. (2001): *Geostatistical Modelling of Petrophysical Data of Oil Fields in the Northern Croatia*. EAGE, Extended abstract book, 63rd Conference and Technical Exhibition.
- Isaaks, E. H., Srivastava, R. M. (1989): *Applied Geostatistics*, Oxford University Press, New York.
- Jensen, J. L., Corbett, P. W. M., Pickup, G. E., Ringrose (1996): Permeability semivariograms, geological structure, and flow performance, *Mathematical Geology*, 28, 4, p. 419-435.
- Jensen, J. L., Lake, L. W., Corbett, P. W. M., Goggin, D. J. (2000): *Statistics for Petroleum Engineers and Geoscientists*, Elsevier Science B. V., Amsterdam.
- Journel, A. G., Huijbregts, C. J. (1978): *Mining Geostatistics*, Academic Press, Orlando.
- Malvić, T. (2003a): *Oil-Geological Relations and Probability of Discovering New Hydrocarbon Reserves in the Bjelovar Sag* (also published in Croatian: *Naftnogeološki odnosi i vjerojatnost pronalaska novih zaliha ugljikovodika u bjelovarskoj uleknini*), Dissertation, University of Zagreb, Faculty of Mining, Geology and Petroleum Engineering, Zagreb.
- Malvić, T. (2003b): One Dimensional Semivariogram and Statistical Analysis in Reservoir Units of the Bjelovar Sag, *Nafta*, 54, 7-8, p. 267-274.
- Malvić, T., Velić, J., Peh, Z. (2005): Qualitative-quantitative analyses of depth and lithological composition influence on Lower Pontian sandstones porosity in the central part of Bjelovar sag (Croatia), *Geologia Croatica*, 58, 1.
- Pannatier, Y. (1996): *VARIOWIN: Software for Spatial Data Analysis in 2D*, Springer-Verlag, New York.
- Peeters, M., Allen, D., Gomes, R., Kristiansen, J. I. (1999): Invasion in space and time, SPWLA 40th Annual Logging Symposium, May 31 - June 3, 1999.
- Thomas, H. E., Smith, J. W. (1970): Caliper location of leached zones in Colorado oil shale, *Log Anal*, 11, 4, p. 12-16.